文章编号：1003-1421(2026)07-0182-12
引用格式：陈子彧，彭晔，宋宗莹，等. 基于时空域特征融合的永磁同步电机故障诊断方法[J]. 铁道运输与经济，2026，48(7)：182-193.
CHEN Ziyu，PENG Ye，SONG Zongying，et al. Permanent Magnet Synchronous Motor Fault Diagnosis Method Based on Spatiotemporal Feature Fusion[J]. Railway Transport and Economy，2026，48(7)：182-193.

基于时空域特征融合的永磁同步电机故障诊断方法

陈子彧[1]，彭　晔[2]，宋宗莹[2]，陶润琦[3]，徐琰淞[1]，彭　涛[1]

(1.中南大学 自动化学院，湖南 长沙　410083；2.中国神华能源股份有限公司 煤炭运输部，北京　100011；3.北京全路通信信号研究设计院集团有限公司 安全控制技术研究院，北京　100070)

摘　要：针对现有永磁同步电机故障诊断方法主要依赖单一电流时序信号而忽略其空间信息造成复杂工况下诊断准确度不高的问题，提出一种基于时空域特征融合的永磁同步电机智能故障诊断方法。首先，提出构建一种基于切比雪夫-双向门控循环单元与时空域多尺度变换器的融合模型；其次，提出了基于切比雪夫-双向门控循环单元与时空域多尺度变换器的融合模型的故障诊断方法，实现永磁同步电机时空域融合特征提取和故障诊断。仿真结果表明，单一空域或时域特征及其简单拼接难以捕获复杂时空耦合关系，所提方法可弥补仅依赖拓扑或时序信息建模的缺陷，获得更具判别力与鲁棒性的特征表征，为永磁同步电机健康管理提供了一种具有参考价值的诊断方案。

关键词：故障诊断；时空域特征建模；多域多尺度融合；切比雪夫图网络；全局注意力；永磁同步电机
中图分类号：U279　　**文献标识码**：A　　**DOI**：10.16668/j.cnki.issn.1003-1421. 20260206002

Permanent Magnet Synchronous Motor Fault Diagnosis Method Based on Spatiotemporal Feature Fusion

CHEN Ziyu[1]，PENG Ye[2]，SONG Zongying[2]，TAO Runqi[3]，XU Yansong[1]，PENG Tao[1]

(1. School of Automation, Central South University, Changsha 410083, Hunan, China; 2. Coal Transportation Department, China Shenhua Energy Co., Ltd., Beijing 100011, China; 3. Safety Control Technology Research Institute, China Railway Signal & Communication Research and Design Institute Group Co., Ltd., Beijing 100070, China)

Abstract: To address the issue that existing permanent magnet synchronous motor (PMSM) fault diagnosis methods primarily rely on single current time-series signals while neglecting spatial information, resulting in low diagnostic accuracy under complex operating conditions, this paper proposes an intelligent fault diagnosis method for PMSMs based on spatiotemporal feature fusion. First, a fusion model based on Chebyshev-bidirectional gated recurrent unit (BiGRU) and a spatiotemporal multi-scale Transformer (CBiGRU-STMTF) was developed. Subsequently, a fault diagnosis method based on the CBiGRU-STMTF model is proposed to enable spatiotemporal feature extraction and fault diagnosis for permanent magnet synchronous motors. The simulation

收稿日期：2026-02-06　　**修订日期**：2026-06-12
通信作者：宋宗莹(1981—)，男，河南荥阳人，中国神华能源股份有限公司煤炭运输部正高级工程师。
基金项目：国家能源投资集团有限责任公司科技创新项目(GJNY-22-7)；中南大学轨道交通节能控制与安全监测湖南省重点实验室资助项目(2017TP1002)

results show that isolated spatial or temporal features, as well as their simple concatenation, struggle to capture complex spatiotemporal relationships. The proposed method addresses the limitations of models relying solely on topological or temporal information, yielding more discriminative and robust feature representations. This provides a valuable diagnostic solution for the health management of permanent magnet synchronous motors.

Keywords: Fault Diagnosis; Spatiotemporal Feature Modeling; Multi-Domain Multi-Scale Fusion; Chebyshev Graph Network; Global Attention; Permanent Magnet Synchronous Motor

0　引言

随着工业自动化的快速发展，永磁同步电机(Permanent Magnet Synchronous Motor，PMSM)凭借其高效率、高功率密度和精准调速特性，已成为轨道交通装备的核心驱动组件。作为轨道交通车辆牵引传动系统的关键部件，PMSM将电能转化为机械能，为车辆提供动力，其运行状态对于轨道交通车辆的安全运行至关重要。近年来，围绕列车牵引能耗计量、运行图节能优化与再生制动能量利用等问题已开展了大量研究[1-2]；同时，在牵引供电方面，学者针对光伏储能等新能源接入牵引网进行技术探索，为牵引系统能量管理提供了新的工程路径[3]。研究表明，永磁体失磁故障在永磁同步电机各类故障中仅次于轴承磨损，故障占比超过20%，已成为牵引系统的第二大故障类型，对车辆运行的安全性与可靠性构成重要威胁。然而，电机长期在启停频繁、负载波动和复杂振动等工况下运行，温度、湿度、路况等复杂环境变化，都可能引发电机部件老化退化甚至导致电机故障的发生[4]，轻则影响电机正常运行，影响车辆运行效率和灵活性[5]，重则引发车辆停车甚至事故，造成设备、车辆损失，严重影响人们出行效率和安全。因此，实现永磁同步电机实时精准故障诊断，对于保障轨道交通车辆可靠、安全运行具有重要意义[6]。

近年来，基于单一域特征深度学习模型的故障诊断方法在PMSM健康管理领域取得突破性进展[7-9]。冯莉等[10]提出一种基于前馈神经网络的PMSM故障诊断方法，融合快速傅里叶变换和短时傅里叶变换等提取电流信号的单一频域特征，实现了对单管开路故障、同桥臂双管开路故障等PMSM逆变器开路故障诊断。Kim等[11]提出了一种基于定子电流运行补偿与卷积神经网络的变工况PMSM故障诊断方法，通过无测速重采样与主运行分量相减并重标定2阶段提取电流信号的单一时域特征，实现了对轴承故障、匝间短路、退磁等PMSM故障诊断。Ren等[12]提出了一种无监督异常检测的PMSM故障诊断方法，通过提取振动信号的单一时域特征实现了对定子匝间、线圈间短路等PMSM故障诊断。但这些方法仅依赖于从单一域特征获得训练知识，对复杂工况下时空耦合特征的敏感性不足，导致工况变化与噪声干扰下的故障诊断精度不高。

多域特征故障诊断方法获得普遍关注[13-14]。Wang等[15]提出了一种残差电流融合和概率神经网络的PMSM故障诊断方法，通过提取电流信号的频域和时域特征实现了对开关开路、匝间短路等PMSM故障诊断。Li等[16]提出一种基于生成对抗网络与优化稀疏自编码器的小样本PMSM故障诊断方法，利用电流信号的时域和序分量域特征实现匝间短路单一故障诊断。上述这些基于多域特征的PMSM故障诊断方法，虽然通过联合时域特征与其他域特征在一定程度上弥补了单一域特征表征不足，但大多只利用单源电流信号，并未显式构建三相电流的空间拓扑表征，闫国华等[17]提出一种基于多尺度卷积神经网络与双向长短期记忆网络的PMSM故障诊断方法，通过提取振动与电流信号融合的全局和局部特征实现了对PMSM匝间短路、均匀退磁及其复合故障的诊断。Lee等[18]提出了一种基于图卷积神网络和长短期记忆网络的轴承故障诊断方法，通过联合挖掘传感器间结构关联与长短时序依赖，实现了轴承故障诊断。Singh等[19]提出一种基于图注意力网络和长短期记忆网络的轴承故障检测方法，通过结合长短期记忆网络建模故障演化的时间依赖，实现了不同工况下的轴承故障诊断。上述方法虽然能够从不同域提取故障信息，但大多未充分结合时序信号的空间拓扑关系，且在特征融合层面多采用简单拼接或浅层交互方式，难以实现不同域特征在多尺度上的有效对齐，导致复杂环境下的判别能力仍然

受限。尽管现有研究已在多域特征故障诊断方面取得了一定进展，但将图神经网络与时序网络结合用于PMSM故障诊断的研究尚不多见。

随着深度学习在多域特征融合中的不断发展，现有研究开始探索利用具有全局依赖建模能力的网络结构进一步提升多源信息的协同表征能力。相较于传统卷积网络或循环网络侧重局部感受野或序列递推建模，Transformer依托自注意力机制能够在全局范围内建立不同域、不同尺度特征之间的关联，为故障诊断中的多域信息深度融合提供了新的研究思路。Ding等[20]将振动信号的时频表征作为多通道输入，引入时间-频率Transformer以捕获时频信息的跨尺度关联。Hou等[21]进一步在时域/频域特征并行提取的基础上，利用改进Transformer实现多特征融合与分类。Zhang等[22]针对多传感器信号的时间对应关系，提出分段对齐的特征融合Transformer，实现多域信息的细粒度交互与全局建模。

为此，提出了一种基于时空域特征融合的永磁同步电机故障诊断方法，旨在挖掘三相电流信号空间拓扑关系，对不同域特征在不同尺度进行深度融合。研究提出了一种基于切比雪夫-双向门控循环单元(Bidirectional Gated Recurrent Unit，BiGRU)与时空域多尺度变换器(Transformer)的融合模型(CBiGRU-STMTF模型)，采用K近邻(K-Nearest Neighbors，KNN)算法对原始电流信号构图，构建切比雪夫图网络作为空间特征提取器，提取电流信号空间拓扑特征；构建引入全局注意力机制的BiGRU网络作为时域特征提取器，获取电流信号关键时序特征并抑制噪声干扰；构建时空域多尺度Transformer融合器，实现电流信号时空域不同特征在不同尺度上的对齐、融合与聚合，形成更具判别性的联合表征；研究提出了基于CBiGRU-STMTF模型的PMSM故障诊断方法，在模型末端配置分类器完成故障分类，在工况变化与噪声干扰下有效提高故障诊断精度、显著降低误判漏判率，适用于轨道交通车辆永磁同步电机运行状态的智能健康监测。

1　基于CBiGRU-STMTF模型的故障诊断

1.1　CBiGRU-STMTF模型构建

基于单一时间域或单一空间域等传统故障特征提取方案会带来故障信息扑捉不足、不同域故障特征间信息割裂和尺度不一致等问题，提出了一种基于CBiGRU-STMTF的融合模型构建方法，主要包含3个模块：基于切比雪夫网络的空间特征提取，基于全局注意力BiGRU网络的时间特征提取和时空域多尺度Transformer融合。CBiGRU-STMTF模型的构成示意图如图1所示。

1.1.1　基于切比雪夫网络的空域特征提取

基于切比雪夫网络的空域特征提取模块，采用基于KNN算法图构建方法[23]，对经标准化的PMSM三相电流信号时间序列样本构建图节点空间特征矩阵，再经构建切比雪夫网络得到空间域特征。

对时间序列样本集构建图节点特征矩阵，公式如下。

$$\boldsymbol{X}_i=\left[\boldsymbol{d}_i^{\top}\right]=\begin{bmatrix}x_{1i}\\x_{2i}\\\vdots\\x_{Mi}\end{bmatrix} \tag{1}$$

式中：$\boldsymbol{X}_i$表示第i个时序样本$\boldsymbol{d}_i$经转置构成的第i个图节点特征矩阵；x_{mi}表示第i个节点特征矩阵的第m行图节点；m表示时序样本中采样点序号，$m=1,2,\cdots,M$；M为采样点总数；$\boldsymbol{d}_i^{\top}$表示第i个时序样本d_i的转置矩阵，$i=1,2,\cdots,N$，N表示时序样本集包含的样本总数。

其中，第m个节点对应第m个采样时刻的三相电流联合状态，节点特征可理解为该时刻a，b，c三相电流在空间中的瞬时表征。

计算图节点特征矩阵$\boldsymbol{X}_i$中任意两节点间的欧氏距离。

$$\boldsymbol{dist}_i(m,j)=\left\|x_{mi}-x_{ji}\right\|_2 \quad m,j=1,2,\cdots,M;\ j\neq m \tag{2}$$

式中：x_{ji}表示第i个节点特征矩阵的第j行图节点；$\|\cdot\|_2$表示$L2$范数；$\boldsymbol{dist}_i(m,j)$表示第i个图节点特征矩阵中节点m与节点j之间的距离矩阵，距离越小表示两节点在多维特征空间越相似。

对每一个节点m，将与其对应的所有距离按从小到大排序，选取距离最小的前k个邻居节点索引，构建第i个图节点特征矩阵对于每一个节点m前k个邻居节点的邻接矩阵$\boldsymbol{A}_i$。需要说明的是，k值决定图结构的稀疏程度与局部连通性：k过小易造成图连通性不足、空间相关性表达不充分，k过大

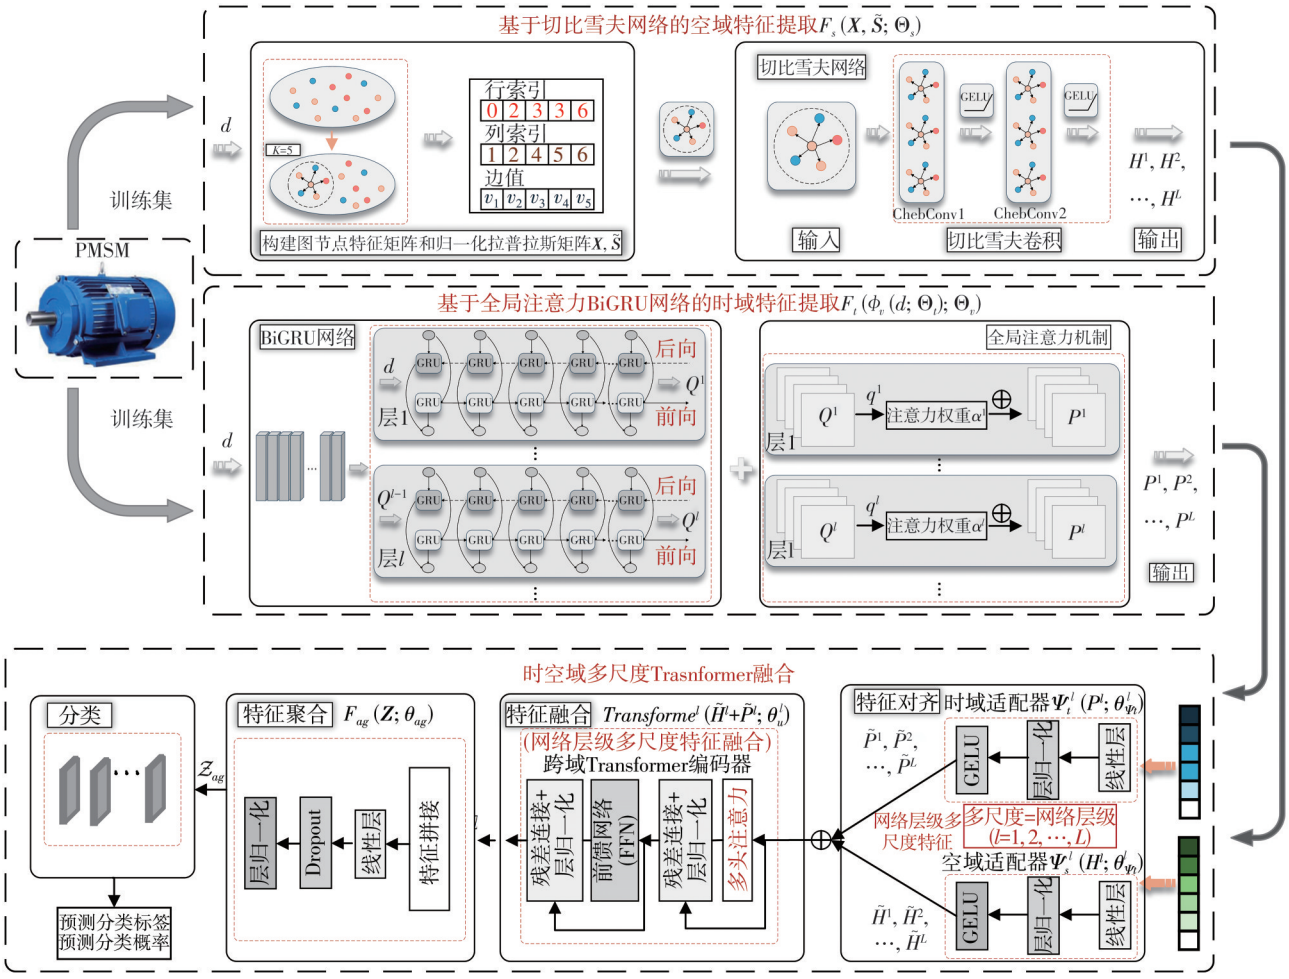

图1　CBiGRU-STMTF模型的构成示意图

Fig.1　Architecture of CBiGRU-STMTF model

则会引入冗余连接并增加计算开销。具体做法为：在固定其他参数与训练策略的条件下，采用贝叶斯优化(顺序模型优化)在候选集合上迭代搜索(前若干次随机初始化，其后按采集函数选择下一组候选)，进一步地，在最优值附近对k做扰动并统计验证集指标得到最优值。利用得到的第i个图节点特征矩阵$\boldsymbol{X}_i$、邻接矩阵$\boldsymbol{A}_i$以及对应第i个时序样本d_i的类别标签y_i，构建第i个有标签图样本$g_i=(\boldsymbol{X}_i,\ \boldsymbol{A}_i,\ y_i)$，以及时间序列样本集对应的图样本集。

对构建的图样本构造归一化拉普拉斯矩阵。

$$\boldsymbol{S}_i=\boldsymbol{I}-\boldsymbol{D}_i^{-1/2}\boldsymbol{A}_i\boldsymbol{D}_i^{-1/2} \tag{3}$$

式中：$\boldsymbol{S}_i$为第i个图样本构造的归一化拉普拉斯矩阵；$\boldsymbol{I}$为单位矩阵；$\boldsymbol{D}_i$为第i个图样本的度矩阵；$\boldsymbol{A}_i$为第i个图节点特征矩阵的邻接矩阵。

将$\boldsymbol{S}_i$的特征值通过线性变换将特征值映射到[-1，1]区间，得到第i个经特征值缩放后的拉普拉斯矩阵。

$$\tilde{\boldsymbol{S}}_i=\frac{2}{\lambda_{\max}(\boldsymbol{S}_i)}\boldsymbol{S}_i-\boldsymbol{I} \tag{4}$$

式中：$\tilde{\boldsymbol{S}}_i$表示第i个图样本经特征值缩放后的拉普拉斯矩阵；$\lambda_{\max}$为$\tilde{\boldsymbol{S}}_i$的最大特征值。

构建切比雪夫网络，获得网络输出为

$$\boldsymbol{H}_i^L=F_s(\boldsymbol{X}_i,\ \tilde{\boldsymbol{S}}_i;\ \Theta_s) \tag{5}$$

式中：$\boldsymbol{H}_i^L$表示以第i个图样本的图节点特征矩阵$\boldsymbol{X}_i$和经缩放后归一化拉普拉斯矩阵$\tilde{\boldsymbol{S}}_i$作为输入、以Θ_s为网络参数经L层切比雪夫网络输出的第i个图节点特征(也即空间域特征)；F_s表示构建的切比雪夫网络；Θ_s表示切比雪夫网络参数集合。

具体地，第l层切比雪夫网络的输出为

$$\boldsymbol{H}_i^L=F_s(\boldsymbol{H}_i^{l-1},\ \tilde{\boldsymbol{S}}_i;\ \Theta_s)=\sigma\Big(\sum_{q=0}^{Q-1}T_q(\tilde{\boldsymbol{S}}_i)\boldsymbol{H}_i^{l-1}\Theta_q^l\Big) \tag{6}$$

式中：$\boldsymbol{H}_i^L$表示以第$l-1$层输出$\boldsymbol{H}_i^{l-1}$和经缩放后归

一化拉普拉斯矩阵$\tilde{\boldsymbol{S}}_i$作为输入经第l层切比雪夫网络输出的第i个图节点特征(即空间域特征)；H_i^{l-1}表示经第$l-1$层切比雪夫网络输出的第i个图节点特征(即空间域特征)；$T_q(\tilde{\boldsymbol{S}}_i)$表示在$\tilde{\boldsymbol{S}}_i$上计算得到的第$q$阶切比雪夫多项式；$\Theta_q^l$表示第$l$层切比雪夫网络中对应第$q$阶切比雪夫多项式的可学习参数；$\sigma(\cdot)$表示非线性激活函数ReLU；$Q$表示切比雪夫多项式阶数，决定切比雪夫图卷积在图上的感受野范围。

当Q取值较小时，模型对更远邻域的空间相关性建模能力不足；当Q取值过大时，虽然可引入更大范围的邻域信息，但易带来过平滑风险并显著增加计算复杂度。具体做法为：在固定其他参数与训练策略的条件下，采用贝叶斯优化(顺序模型优化)在候选集合上迭代搜索(前若干次随机初始化，其后按采集函数选择下一组候选)，进一步地，在最优值附近对Q做扰动并统计验证集指标得到最优值。第l层切比雪夫网络输出的空间域特征为：$H^l=\left[H_1^l,\ H_2^l,\ \cdots,\ H_N^l\right]$。取$l=1,\ 2,\ \cdots,\ L$，经$L$层切比雪夫网络输出的空间域特征，即公式(5)最终输出的空间域特征为：$H^1,\ H^2,\ \cdots,\ H^L$。

1.1.2　基于全局注意力BiGRU网络的时域特征提取

基于全局注意力BiGRU网络的时域特征提取模块，通过构建基于全局注意力机制的BiGRU网络，动态计算输入序列每个采样点的注意力权重，生成时间域特征。

构建基于全局注意力机制的BiGRU网络，获得网络输出为

$$P_i^L=F_t(\phi_v(d_i;\ \Theta_t);\ \Theta_v) \tag{7}$$

式中：P_i^L表示以第i个时序样本d_i为输入，以Θ_t，Θ_v为模型参数经L层全局注意力BiGRU网络输出的时间域特征；F_t表示构建的基于全局注意力机制的BiGRU网络；ϕ_v表示BiGRU网络；Θ_t表示BiGRU网络参数集合；$F_t(\cdot;\ \Theta_v)$表示全局注意力机制；Θ_v表示全局注意力机制参数集合。

具体地，第l层BiGRU网络的输出为

$$Q_i^l=\phi_v^l(Q_i^{l-1};\ \Theta_t)=[\boldsymbol{q}_{i,\ 1}^l,\ \boldsymbol{q}_{i,\ 2}^l,\ \cdots,\ \boldsymbol{q}_{i,\ M}^l]^{\top} \tag{8}$$

式中：Q_i^l表示以第$l-1$层输出Q_i^{l-1}作为输入经第l层BiGRU网络得到的对应第i个时序样本d_i的输出；ϕ_v^l表示第l层BiGRU网络；Q_i^{l-1}表示经第$l-1$层BiGRU网络得到的对应第i个时序样本的输出；$\boldsymbol{q}_{i,\ m}^l$表示第l层BiGRU网络中对应第i个时序样本d_i第m个采样点处、经过前向GRU和后向GRU处理后拼接得到的特征向量；$[\cdot]^{\top}$表示转置。

计算特征向量$\boldsymbol{q}_{i,\ m}^l$重要性得分，并通过Softmax归一化得到其注意力权重。

$$\alpha_{i,\ m}^l=\frac{\exp(v^{\top}\tanh(W_h\boldsymbol{q}_{i,\ m}^l+b))}{\sum_{t=1}^{M}\exp(v^{\top}\tanh(W_h\boldsymbol{q}_{i,\ t}^l+b))} \tag{9}$$

式中：$\alpha_{i,\ m}^l$表示第l层BiGRU网络中特征向量$\boldsymbol{q}_{i,\ m}^l$的归一化注意力权重；W_h，v，b表示可学习参数。

经第l层全局注意力BiGRU网络的输出为

$$P_i^l=F_t^l(Q_i^l;\ \Theta_v)=\sum_{m=1}^{M}\alpha_{i,\ m}^l\boldsymbol{q}_{i,\ m}^l \tag{10}$$

式中：P_i^l表示以第l层BiGRU网络输出Q_i^l作为输入经第l层全局注意力机制得到的对应第i个时序样本d_i的输出(也即时间域特征)。

第l层全局注意力BiGRU网络输出的时间域特征为：$P^l=\left[P_1^l,\ P_2^l,\ \cdots,\ P_N^l\right]$。取$l=1,\ 2,\ \cdots,\ L$，经$L$层全局注意力BiGRU网络输出的时间域特征，即公式(7)最终输出的时间域特征为：$P^1,\ P^2,\ \cdots,\ P^L$。

1.1.3　时空域多尺度Transformer融合

时空域多尺度Transformer融合模块，通过基于切比雪夫网络的空域特征提取和基于全局注意力BiGRU网络的时域特征提取这2层交互机制，经特征对齐、特征融合和特征聚合3阶段处理实现空间域特征与时间域特征信息融合，从而有效捕捉故障信号在不同时空域不同尺度上的耦合特性。

构建第l层空域适配器，对切比雪夫网络的空域输出特征进行空域适配处理，得到空域适配输出特征。

$$\tilde{H}^l=\psi_s^l(H^l;\ \theta_{\psi_s}^l) \tag{11}$$

式中：$\tilde{H}^l$表示以切比雪夫网络$F_s(\boldsymbol{X}_i,\ \tilde{\boldsymbol{S}}_i;\ \Theta_s)$输出的空间域特征$H^l$为输入，经第$l$层空域适配器$\psi_s^l(H^l;\ \theta_{\psi_s}^l)$输出的第$l$层空域适配特征；$\psi_s^l$表示第$l$层空域适配器；$\theta_{\psi_s}^l$表示第$l$层空域适配器的可学习参数集合，取$l=1,\ 2,\ \cdots,\ L$，经$L$层空域适配器输出的空域适配特征为：$\tilde{H}^1,\ \tilde{H}^2,\ \cdots,\ \tilde{H}^L$。

构建第l层时域适配器得到时域适配输出特征。

$$\tilde{P}^l=\psi_t^l(P^l;\ \theta_{\psi_t}^l) \tag{12}$$

式中：$\tilde{P}^l$表示以全局注意力BiGRU网络$F_t(\phi_v(d_i;$

Θ_t)；Θ_v)输出的时间域特征P^l为输入，经第l层时域适配器$\psi_t^l(P^l;\ \theta_{\psi_t}^l)$输出的第$l$层时域适配特征；$\psi_t^l$表示第$l$层时域适配器；$\theta_{\psi_t}^l$表示第$l$层时域适配器的可学习参数集合。

经空域和时域适配器处理后，得到的空域适配输出与时域适配输出维度相同，实现特征对齐。取l = 1，2，…，L，经L层时域适配器输出的时域适配特征为：$\tilde{P}^1$，$\tilde{P}^2$，…，$\tilde{P}^L$。跨域对齐通过多头注意力机制完成。具体而言，将空域特征作为查询，将时域特征作为键/值，通过两域特征之间的相似性计算并归一化得到跨域注意力权重，再对目标域特征进行加权汇聚形成对齐后的表示。多头注意力进一步将特征映射到多个子空间并行建模，使不同注意力头能够分别关注不同频带、相位差或耦合模式的对应关系，最终融合各头输出得到更充分的跨域对齐特征。

将对齐后空间域特征$\tilde{H}^l$与时间域特征$\tilde{P}^l$进行融合，得到融合特征为

$$z^l = Transformer^l(\tilde{H}^l + \tilde{P}^l;\ \theta_u^l) \tag{13}$$

式中：z^l表示以空间域特征$\tilde{H}^l$与时间域特征$\tilde{P}^l$为输入，经Transformer融合后输出的融合特征；$Transformer^l$表示第l层Transformer融合器；θ_u^l为Transformer融合器参数集。

取l = 1，2，…，L，经L层Transformer融合器输出的融合特征为：z^1，z^2，…，z^L。

对融合输出特征z^1，z^2，…，z^L按行进行拼接，构成L层融合输出特征的拼接矩阵。

$$\boldsymbol{Z} = \left[z^1 z^2 \cdots z^L\right] \tag{14}$$

式中：$\boldsymbol{Z}$表示L层融合输出特征的拼接矩阵。

构建特征聚合器，得到聚合输出特征。

$$\mathcal{Z}_{ag} = F_{ag}(\boldsymbol{Z};\ \theta_{ag}) \tag{15}$$

式中：$\mathcal{Z}_{ag}$表示以L层融合输出特征的拼接矩阵$\boldsymbol{Z}$为输入经特征聚合器输出的聚合特征；F_{ag}表示特征聚合器；θ_{ag}为聚合器模型参数。

将聚合输出特征$\mathcal{Z}_{ag}$送入分类器，得到预测分类标签和预测分类概率。

1.2　基于CBiGRU-STMTF模型的故障诊断

提出基于CBiGRU-STMTM模型的PMSM故障诊断方法，基于CBiGRU-STMTF模型的故障诊断方法如图2所示，包括模型训练阶段与模型测试阶段2部分。

模型训练阶段分如下步骤。①将采集得到的原始PMSM电流数据输入数据预处理模块，数据预处理包括去噪、标准化和基于滑动窗口的数据分割，为抑制采集噪声并尽可能保留与故障相关的瞬态信息，分别对三相电流信号采用离散小波软阈值去噪

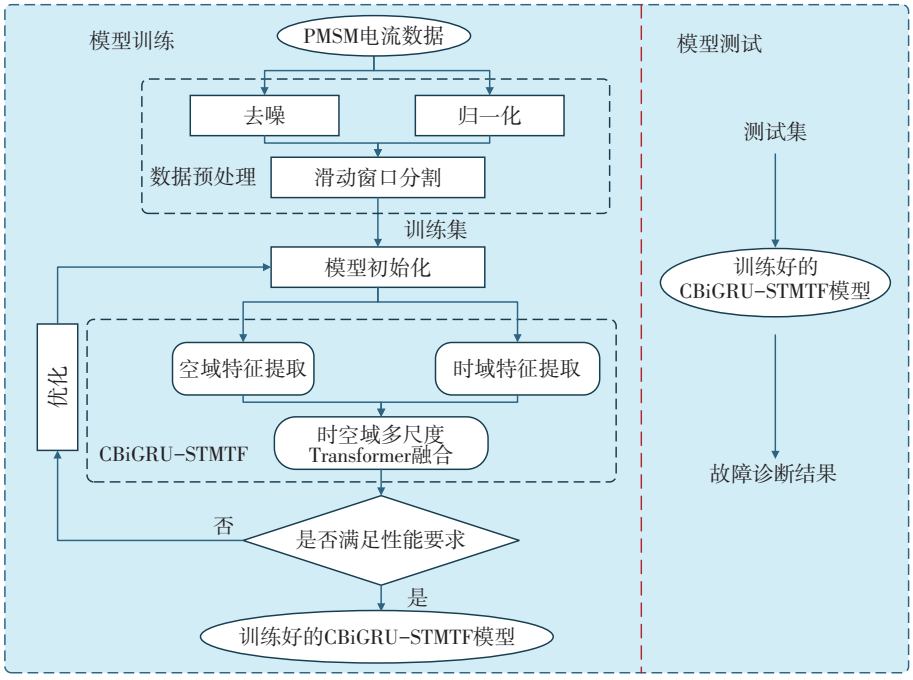

图2　基于CBiGRU-STMTF模型的故障诊断方法

Fig.2　Fault diagnosis method based on CBiGRU-STMTF model

处理，其中阈值依据通用阈值准则确定，并通过软阈值函数完成信号重构。为消除不同特征量纲差异并提高模型训练稳定性，进一步对去噪后的各相电流信号进行Z-score标准化。标准化过程中所用均值和标准差均由训练集统计获得，并统一用于验证集和测试集的同尺度变换。②对模型进行初始化。③对构建的CBiGRU-STMTF模型进行训练，一方面通过空间特征提取支路挖掘不同传感通道间的空间关联，另一方面通过时间特征提取支路建模故障演化的时序依赖关系，利用时空域多尺度Transformer融合模块在不同时间尺度和不同域特征之间进行注意力建模和特征对齐、特征融合、特征聚合，从而获得具有更强可分性的联合特征表征；训练过程中以诊断精度、损失函数和收敛稳定性等指标为约束，采用梯度下降不断迭代更新网络参数，并根据预设性能阈值判断模型是否满足分类要求；若尚未达标，则继续优化，否则得到可部署的CBiGRU-STMTF诊断模型。

在模型测试阶段，将与训练阶段相同流程预处理后的测试集样本输入到已训练好的CBiGRU-STMTF模型中，模型利用学习到的多域多尺度特征表征对输入样本进行学习和推理，输出对应的故障类别标签，计算精确率、召回率、$F1$分数指标和加权AUC。

精确率P_{rec}定义为

$$P_{\mathrm{rec}}=\frac{\sum TP}{\sum TP+\sum FP} \tag{16}$$

召回率R_{call}定义为

$$R_{\mathrm{call}}=\frac{\sum TP}{\sum TP+\sum FN} \tag{17}$$

式中：$\sum TP$表示测量数据应归属于某一类别且结果被识别为该类别的样本数量；$\sum FP$表示测量数据不属于上述任何类别但被识别为该类别的样本数量；$\sum FN$表示测量数据应归属于某一类别但实际识别结果不属于该类别的样本数量。

$F1$分数定义为

$$F1=2\times\frac{Prec\times Recall}{Prec+Recall} \tag{18}$$

加权AUCA_{wauc}定义为

$$A_{wauc}=\sum_{k=1}^{K}\frac{N_k}{N}AUC_k \tag{19}$$

式中：K表示类别总数；N_k表示第k类样本数量；N表示全部样本数量；AUC_k表示将第k类视为正类、其余类别视为负类时对应ROC曲线下的面积。

ROC曲线用于表征分类模型在不同判别阈值下真正例率与假正例率之间的变化关系，从而反映模型整体判别能力。通过上述训练-测试闭环流程，可以实现PMSM高精度智能故障诊断。

2　仿真分析与结果

2.1　数据集介绍

仿真所用数据集来自于硬件在环的轨道交通车辆牵引电机运行状态监测半实物平台[24-25]。该平台由dSPACE实时仿真器、高速列车牵引控制单元、信号调节器等组成。高速列车牵引控制单元由牵引变压器、牵引变频器、PMSM组成，均通过dSPACE实时仿真器实现。为了测试故障诊断性能，故障注入单元实现了对匝间短路、永磁体失磁等典型故障的模拟，上位机通过PyCharm进行模型编译与参数配置。其中，平台采用信号级故障注入方式，在实时仿真环境中通过设置故障注入时刻、故障类型和故障严重度参数实现典型故障模拟；针对匝间短路故障与永磁体失磁故障，均设置了不同严重度等级，以表征由轻到重的故障演化程度。

数据集由PMSM在1 000 r/min，1 400 r/min和1 600 r/min3种稳定工况下采集的三相电流数据构成，并利用这些稳定工况数据对所提方法进行了验证，数据采样率为20 kHz。数据集包含了每种工况下的3种类型：正常数据、匝间短路故障数据和永磁体失磁故障数据。该数据集共包含18 740个时间序列样本，并按照7∶2∶1的比例划分为训练集、验证集和测试集。

为增强方法的可复现性与工程实用性，补充给出关键超参数的调优范围与选择依据。对于KNN构图近邻数k与切比雪夫多项式阶数Q，先给定离散候选集合$k\in\{3,5,7,9,11,13\}$，$Q\in\{2,3,4,5,6\}$，在固定训练轮数、数据划分与随机种子条件下，采用贝叶斯优化进行顺序搜索，通过代理模型与采集策略在有限评估次数内自动选择下一组候选，从而减少人工试错的主观性。超参数调优范围与选取依据如表1所示。

表1　超参数调优范围与选取依据

Tab.1　Hyperparameter tuning ranges and selection criteria

超参数	候选集合	选择依据	最终取值
KNN近邻数k	{3，5，7，9，11，13}	贝叶斯优化顺序搜索	k = 5
切比雪夫多项式阶数Q	{2，3，4，5，6}	贝叶斯优化顺序搜索	Q = 3

表2　不同转速工况下CBiGRU-STMTF模型诊断性能

Tab.2　Diagnostic performance of CBiGRU-STMTF model under different speed conditions

转速/(r/min)	精确率/%	召回率/%	$F1$/%	加权AUC/%
1 000	95.43	95.36	95.39	99.52
1 400	95.56	95.64	95.60	99.61
1 600	95.12	95.23	95.17	99.46

2.2　消融实验与分析

为验证基于CBiGRU-STMTF模型的故障诊断方法在不同转速工况下的泛化能力，在1 000 r/min，1 400 r/min与1 600 r/min3种工况上进行测试，不同转速工况下CBiGRU-STMTF模型诊断性能如表2所示。可以看出，在3种转速条件下模型均保持较高的分类性能：精确率分别为95.43%，95.56%和95.12%；召回率为95.36%，95.64%和95.23%；$F1$分数为95.39%，95.60%和95.17%；加权AUC为99.52%，99.61%和99.46%。整体上，各指标在不同转速间波动较小，说明所提方法能够在转速变化导致的数据分布偏移下仍保持稳定的判别能力，体现出良好的鲁棒性与工程适用性。

为验证基于CBiGRU-STMTF模型的故障诊断方法的有效性，进一步设置了如下仿真。①基于切比雪夫网络的故障诊断方法(单一空间域)；②基于全局注意力BiGRU网络的故障诊断方法(单一时间域)；③基于CBiGRU-FS的故障诊断方法(基于切比雪夫网络与基于全局注意力BiGRU网络两域特征的简单拼接)；④基于CBiGRU-STMTF模型的故障诊断方法(本研究提出的方法)。分别采用这4种方法进行1 000 r/min与1 400 r/min下6种类型的PMSM故障诊断，得到的结果以混淆矩阵和平均验证指标呈现，消融实验的混淆矩阵如图3所示，消融实验的测试集诊断结果如表3所示。

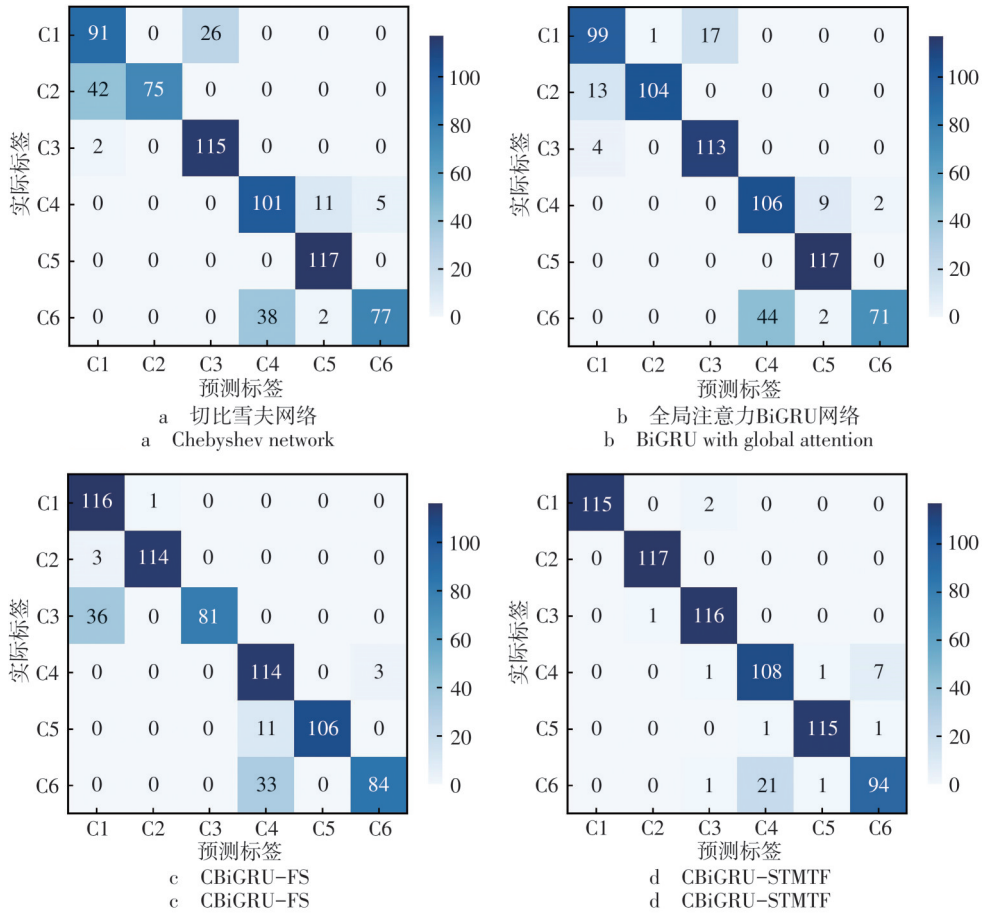

图3　消融实验的混淆矩阵

Fig.3　Confusion matrices of ablation experiments

表3　消融实验的测试集诊断结果　%

Tab.3　Diagnostic results on test set

方法	精确率	召回率	*F*1	加权AUC
切比雪夫网络	84.26	82.05	81.75	98.12
全局注意力BiGRU网络	88.44	86.89	86.64	98.78
CBiGRU-FS	90.45	87.61	87.62	99.12
CBiGRU-STMTF	95.54	95.44	95.43	99.51

由表4和图3的结果可得，基于切比雪夫网络的故障诊断方法(单一空间域)表现最弱，其精确率、召回率与*F*1分数分别仅为84.26%，82.05%和81.75%，并出现大量跨类误判，暴露出传统基于KNN的图结构在建模复杂故障特征方面的局限性；而基于全局注意力BiGRU网络的故障诊断方法(单一时间域)性能虽有所提升，精确率与*F*1分数分别提升至88.44%和86.64%，但仍因缺乏空间耦合关系的建模，在弱故障与正常状态识别中存在混淆，说明单一特征难以完整表征PMSM的复杂时空关联；基于CBiGRU-FS模型的故障诊断方法(基于切比雪夫网络与基于全局注意力BiGRU网络两域特征的简单拼接)通过简单拼接时空特征使精确率提升至90.45%，*F*1分数提升至87.62%，但对复杂时空特征的捕获能力仍然有限；相比之下，本研究提出的基于CBiGRU-STMTF模型的故障诊断方法大幅提升诊断性能，精确率、召回率、*F*1分数均达到95.5%左右，几乎完全消除了跨类误判。从加权AUC指标来看，各方法均表现出较强的类别区分能力，但仍存在明显差异：基于切比雪夫网络的故障诊断方法加权AUC为98.12%，说明其对不同故障类别的整体排序能力相对较弱；基于全局注意力BiGRU网络的故障诊断方法加权AUC提升至98.78%，表明时域建模有助于增强样本可分性；基于CBiGRU-FS模型的故障诊断方法加权AUC进一步提升至99.12%，但提升幅度有限。本研究提出的基于CBiGRU-STMTF模型的故障诊断方法加权AUC达到99.51%，为所有对比方法中最高，说明所提方法能够在类别不均衡背景下，更有效地学习不同故障类别之间的判别特征，使模型对各类别样本输出的预测概率分布更加分离，即正确类别的预测得分更高、错误类别的得分更低，从而获得更强的整体判别与泛化能力。训练过程中的损失曲线如图4所示。

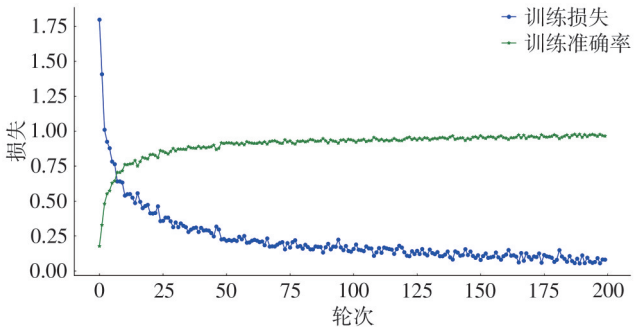

图4　训练过程中的损失曲线

Fig.4　Loss curves during training

为直观展示模型训练过程的收敛性与稳定性，图4展现基于CBiGRU-STMTF模型的故障诊断方法在训练阶段的损失函数随训练轮次的变化曲线。可以看出，训练初期损失迅速下降，表明模型能够快速学习到区分不同故障状态的关键特征；随后损失下降速度逐渐放缓并在后期保持在较低水平，整体呈现快速下降到缓慢收敛再到稳定的典型收敛形态，说明训练过程未出现发散或震荡，模型优化过程较为稳定。与此同时，训练精确率随训练轮次稳步提升并趋于平稳，与损失曲线的收敛趋势一致，进一步验证了训练过程的合理性与模型参数的有效收敛。

2.3　主流方法对比实验与分析

为验证基于CBiGRU-STMTF模型的故障诊断方法与当前主流多域模型故障诊断方法的优越性，具体设置了如下对比实验。①基于图卷积网络与时序卷积网络(GCN-TCN)模型的故障诊断方法；②基于CBiGRU-STMTF模型的故障诊断方法。分别采用这2种方法进行1 000 r/min与1 400 r/min下6种类型的PMSM故障诊断，得到的结果以t分布随机领域嵌入(t-distributed Stochastic Neighbor Embedding，t-SNE)和平均验证指标呈现，2种方法针对目标数据的t-SNE可视化如图5所示，2种方法的测试集诊断结果如表4所示。

由表5和图5的结果可得，采用基于图卷积网络与时序卷积网络(GCN-TCN)模型的故障诊断方法在目标数据上已具备较好的诊断能力，其精确率、召回率与*F*1分数分别达到91.65%，90.56%和91.10%，说明通过图结构空域建模与TCN时域建模的组合能够有效提取PMSM故障的时空特征；但从t-SNE可视化可以看出，GCN-TCN得到的特征

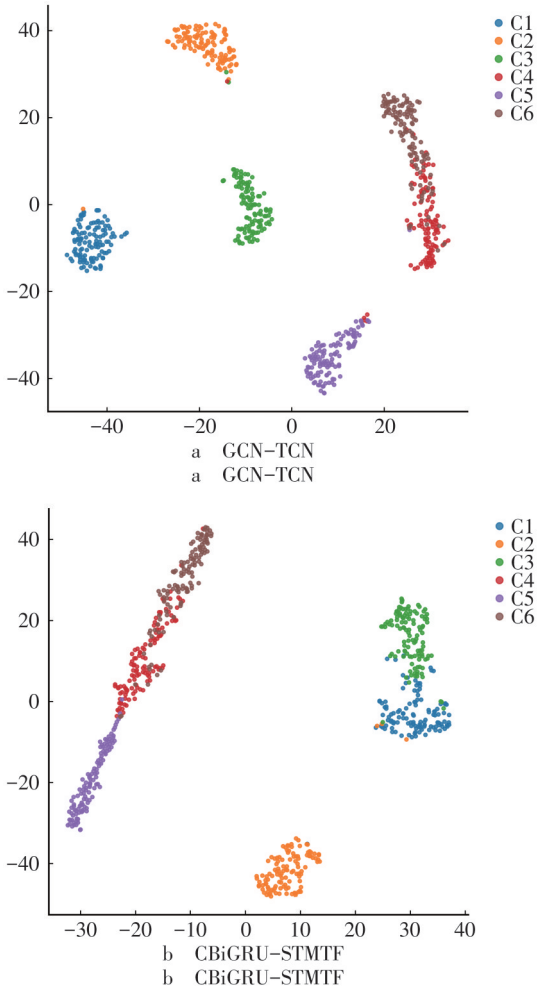

图5　2种方法针对目标数据的t-SNE可视化

Fig.5　T-SNE visualization of two methods on target data

表4　2种方法的测试集诊断结果　%

Tab.4　Diagnostic results of two methods on test set

方法	精确率	召回率	*F*1	加权AUC
GCN-TCN	91.65	90.56	91.10	99.23
CBiGRU-STMTF	95.54	95.44	95.43	99.51

分布仍呈现出一定的类内离散与类间贴近现象，反映出该方法在复杂故障特征的跨域对齐与判别性表征方面仍存在不足。相比之下，研究提出的基于CBiGRU-STMTF模型的故障诊断方法在同一测试集上将精确率、召回率与*F*1分数进一步提升至95.54%，95.44%和95.43%，相较GCN-TCN分别提高3.89，4.88与4.33个百分点；同时，图5中CBiGRU-STMTF的t-SNE结果表现为类内更加紧凑、类间间隔更大，各类样本聚类更加清晰，表明所提出的多尺度对齐融合机制能够在充分保留空域耦合信息的同时增强时空特征的深度交互与判别性，从而有效降低相近故障状态之间的混淆，客观体现了本研究提出的方法相对于GCN-TCN模型的故障诊断方法的优越性。从加权AUC指标来看，基于GCN-TCN模型的故障诊断方法加权AUC为99.23%，说明其在不同故障类别间已具备较强的整体排序区分能力；而基于CBiGRU-STMTF模型的故障诊断方法加权AUC进一步提升至99.51%。该结果表明，所提出的时空域多尺度对齐融合不仅提升了固定阈值下的分类精度(精确率、召回率与F1分数)，同时也能更稳定地拉开各类别的预测得分差距，在类别不均衡条件下表现出更强的整体判别能力与鲁棒性，与t-SNE中更紧凑的类内分布和更清晰的类间边界相一致。

除t-SNE可视化外，时空域多尺度Transformer融合模块中的多头跨注意力权重也可用于增强可解释性。具体地，可导出融合模块中的注意力权重，并在不同注意力头上取平均，得到时间片段和空间节点的关注热力图。将高权重区域重新映射到原始电流序列的对应时间区间及图节点，即可说明模型在诊断时更关注哪些关键时间段和空间耦合关系；进一步可对不同故障类别统计高关注时间段与关键节点的分布差异，从而提升模型决策的可解释性。

需要指出的是，轨道交通车辆牵引电机在实际运行中常伴随测量噪声扰动以及启停、牵引/制动切换等引起的转速非平稳变化，上述因素可能导致电流信号分布发生偏移，从而对故障诊断模型的泛化性能提出更高要求。为进一步评估所提方法在复杂工况下的鲁棒性，后续可在不同信噪比水平下对电流序列施加噪声扰动，采用准确率与宏平均*F*1等指标量化性能随噪声强度与转速变化的趋势，同时可区分稳态段与动态段分别统计结果，以更细致刻画工况变化对诊断性能的影响。

3　结论

为解决PMSM故障诊断中单一域诊断方法难以同时充分挖掘电流信号的时序信息与空间相关性、导致复杂故障识别精度受限的问题，提出了一种基于CBiGRU-STMTF模型的永磁同步电机故障诊断方法，实现空间-时间特征的对齐、融合与聚合，从而

形成更具判别力的融合特征表征，用于PMSM故障识别。所提出的基于切比雪夫-双向门控循环单元与时空域多尺度Transformer的融合模型，主要包含3个模块：基于切比雪夫网络的空间特征提取，基于全局注意力BiGRU网络的时间特征提取和时空域多尺度Transformer融合。该模型能够充分地融合多域多尺度特征，显著提升PMSM故障诊断的准确性与鲁棒性。结果表明，所提方法在精确率、召回率和$F1$分数上分别达到95.54%，95.44%和95.43%，显著降低类别混淆，提升故障诊断准确性。所提方法有效提高了PMSM故障诊断精度，为提升轨道交通车辆电机的故障诊断性能和运行状态健康监测水平提供了参考价值。尽管基于CBiGRU-STMTF模型的永磁同步电机故障诊断方法在空域-时域联合特征提取与多尺度融合方面取得较好效果，但实验主要覆盖有限转速工况，对变速变载与跨平台迁移的适应性仍有提升空间。未来可考虑扩展多工况跨域数据引入迁移学习或自监督预训练以提升泛化能力。

参考文献：

[1] 王清永，钱广民，刘　颖，等. 考虑驾驶策略与再生能利用的城轨列车运行图节能优化[J]. 铁道运输与经济，2024，46(11)：30-38.
WANG Qingyong，QIAN Guangmin，LIU Ying，et al. Energy Saving Optimization of Urban Rail Train Working Diagram Considering Driving Strategy and Regenerative Energy Utilization[J]. Railway Transport and Economy，2024，46(11)：30-38.

[2] 袁　林，郎　春，倪少权，等. 面向列车运行图的高速列车能耗计算方法研究[J]. 铁道运输与经济，2024，46(11)：45-52，195.
YUAN Lin，LANG Chun，NI Shaoquan，et al. Calculation Methods of High Speed Train Energy Consumption Based on Train Working Diagram[J]. Railway Transport and Economy，2024，46(11)：45-52，195.

[3] 安星锟，田奥博，吴　磊，等. 铁路沿线光伏储能接入牵引网技术研究[J]. 铁道运输与经济，2024，46(11)：13-20.
AN Xingkun，TIAN Aobo，WU Lei，et al. Technology of Photovoltaic and Energy Storage Access to Traction Network along Railway Line[J]. Railway Transport and Economy，2024，46(11)：13-20.

[4] FENG X B，WANG B，LIU C H，et al. Research on Inter-Turn Short-Circuit Fault Diagnosis Method Based on High Frequency Voltage Residual for PMSM[J]. CES Transactions on Electrical Machines and Systems，2023，7(3)：256-265.

[5] GE Y，ZHANG F S，REN Y. Adaptive Fault Diagnosis Method for Rotating Machinery with Unknown Faults under Multiple Working Conditions[J]. Journal of Manufacturing Systems，2022，63：177-184.

[6] 张大勇. 铁路交流牵引电机故障诊断技术研究及应用[J]. 中国铁路，2021(5)：1-11.
ZHANG Dayong. Research and Application of Fault Diagnosis Technology for Railway AC Traction Motor[J]. China Railway，2021(5)：1-11.

[7] 蒋爱国，符培伦，谷　明，等. 基于多模态堆叠自动编码器的感应电机故障诊断[J]. 电子测量与仪器学报，2018，32(8)：17-23.
JIANG Aiguo，FU Peilun，GU Ming，et al. Induction Motor Fault Diagnosis Based on Multimodal Stacked Auto-Encoder[J]. Journal of Electronic Measurement and Instrumentation，2018，32(8)：17-23.

[8] 陈岩岩，苏树智，朱彦敏. 跨模态耦合图Transformer故障诊断方法[J]. 宁夏师范大学学报，2025，46(7)：93-103.
CHEN Yanyan，SU Shuzhi，ZHU Yanmin. Fault Diagnosis Method of Cross-Modal Coupled Graph Transformer[J]. Journal of Ningxia Normal University，2025，46(7)：93-103.

[9] CHOUDHARY A，KUMAR Mishra R，FATIMA S，et al. Multimodal Fusion-Based Fault Diagnosis of Electric Vehicle Motor for Sustainable Transportation[J]. IEEE Transactions on Transportation Electrification，2025，11(2)：6249-6266.

[10] 冯　莉，罗洪林，许水清. 采用SDAE-FFNN网络的PMSM逆变器开路故障诊断研究[J]. 重庆理工大学学报(自然科学)，2023，37(8)：99-108.
FENG Li，LUO Honglin，XU Shuiqing. Research on Open Circuit Fault Diagnosis of PMSM Inverter with SDAE－FFNN Network[J]. Journal of Chongqing University of Technology (Natural Science)，2023，37(8)：99-108.

[11] KIM H，HEE Park C，SUH C，et al. Stator Current Operation Compensation (SCOC)：A Novel Preprocessing Method for Deep Learning-Based Fault Diagnosis of Permanent Magnet Synchronous Motors under Variable Operating Conditions[J]. Measurement，2023，221：113446.

[12] REN P Z，ZHU N，PENG D D，et al. Deep Adaptive Wavelet Autoencoder with Mutually Independent Empirical Cumulative Distribution for Unsupervised Motor Anomaly Detection[J].

Engineering Applications of Artificial Intelligence, 2025, 162: 112446.

[13] CHEN Z W, LIANG K T, PENG T, et al. Multi-Condition PMSM Fault Diagnosis Based on Convolutional Neural Network Phase Tracker[J]. Symmetry, 2022, 14(2): 295.

[14] PARK C H, KIM H, SUH C, et al. A Health Image for Deep Learning-Based Fault Diagnosis of a Permanent Magnet Synchronous Motor under Variable Operating Conditions: Instantaneous Current Residual Map[J]. Reliability Engineering & System Safety, 2022, 226: 108715.

[15] WANG Q, TAN Q, GUO C, et al. Fault Diagnosis for Five-Phase PMSM Drive Using Residual Current Fusion and Probabilistic Neural Network[J]. Journal of Power Electronics, 2026, 26(4): 781-793.

[16] LI Y J, WANG Y B, ZHANG Y, et al. Diagnosis of Inter-Turn Short Circuit of Permanent Magnet Synchronous Motor Based on Deep Learning and Small Fault Samples[J]. Neurocomputing, 2021, 442: 348-358.

[17] 闫国华, 胡以怀. 基于多尺度CNN和BiLSTM的船舶推进永磁同步电机故障诊断[J]. 上海海事大学学报, 2024, 45(4): 83-91, 116.
YAN Guohua, HU Yihuai. Fault Diagnosis of Permanent Magnet Synchronous Motors for Ship Propulsion Based on Multi-Scale CNN and BiLSTM[J]. Journal of Shanghai Maritime University, 2024, 45(4): 83-91, 116.

[18] LEE D, CHOO H, JEONG J. GCN-Based LSTM Autoencoder with Self-Attention for Bearing Fault Diagnosis[J]. Sensors, 2024, 24(15): 4855.

[19] SINGH M T, PRASAD R K, MICHAEL G R, et al. Spatial-Temporal Bearing Fault Detection Using Graph Attention Networks and LSTM[EB/OL]. (2024-10-15) [2026-04-08]. https://arxiv.org/abs/2410.11923.

[20] DING Y F, JIA M P, MIAO Q H, et al. A Novel Time-Frequency Transformer Based on Self-Attention Mechanism and Its Application in Fault Diagnosis of Rolling Bearings[J]. Mechanical Systems and Signal Processing, 2022, 168: 108616.

[21] HOU Y D, WANG J J, CHEN Z Q, et al. Diagnosisformer: An Efficient Rolling Bearing Fault Diagnosis Method Based on Improved Transformer[J]. Engineering Applications of Artificial Intelligence, 2023, 124: 106507.

[22] ZHANG X H, WANG H, WANG C Z, et al. Time-Segment-Wise Feature Fusion Transformer for Multi-Modal Fault Diagnosis[J]. Engineering Applications of Artificial Intelligence, 2024, 138: 109358.

[23] LI T F, ZHOU Z, LI S N, et al. The Emerging Graph Neural Networks for Intelligent Fault Diagnostics and Prognostics: A Guideline and a Benchmark Study[J]. Mechanical Systems and Signal Processing, 2022, 168: 108653.

[24] 杨　超, 彭　涛, 阳春华, 等. 高速列车牵引传动系统故障测试与验证仿真平台研究[J]. 自动化学报, 2019, 45(12): 2218-2232.
YANG Chao, PENG Tao, YANG Chunhua, et al. Fault Testing and Validation Simulation Platform for Traction Drive System of High Speed Trains[J]. Acta Automatica Sinica, 2019, 45(12): 2218-2232.

[25] YANG C H, YANG C, PENG T, et al. A Fault-Injection Strategy for Traction Drive Control Systems[J]. IEEE Transactions on Industrial Electronics, 2017, 64(7): 5719-5727.

(责任编辑　金　晶)

(上接第170页)

铁道标准设计, 2018, 62(4): 35-40.
XU Bo. Research on Forward Design Method of Railway Engineering Based on BIM Technology[J]. Railway Standard Design, 2018, 62(4): 35-40.

[13] 刘　奥. 武汉地铁2号线常青花园车辆段BIM设计[J]. 铁路技术创新, 2015(3): 81-84.

[14] 菅云硕, 范文杰, 许海丰, 等. 铁路工程BIM模型轻量化技术研究[J]. 铁道运输与经济, 2023, 45(5): 99-104.
JIAN Yunshuo, FAN Wenjie, XU Haifeng, et al. Research on Lightweight Technology of BIM Model for Railway Engineering[J]. Railway Transport and Economy, 2023, 45(5): 99-104.

[15] 袁敦磊, 王晓刚, 刘学福, 等. 基于BIM技术的高速铁路设备运维管理关键技术及总体设计方案研究[J]. 铁道运输与经济, 2023, 45(12): 107-114.
YUAN Dunlei, WANG Xiaogang, LIU Xuefu, et al. Research on Key Technologies and Overall Design Scheme of High Speed Railway Equipment Operation and Maintenance Management Based on BIM Technology[J]. Railway Transport and Economy, 2023, 45(12): 107-114.

(责任编辑　魏　然)